

袁世一. 基于粒子群优化 GRU 的粮食产量预测[J]. 智能计算机与应用, 2024, 14(8): 109–114. DOI: 10.20169/j.issn.2095-2163.240818

基于粒子群优化 GRU 的粮食产量预测

袁世一

(中国农业科学院 农业信息研究所, 北京 100081)

摘要: 粮食产量预测是关系国计民生的重要问题,为了提高粮食产量预测的精度,本文提出了一种基于粒子群优化算法(PSO)–门控循环单元(Particle Swarm Optimization–Gate Recurrent Unit, PSO–GRU)的粮食产量预测模型。该模型利用 PSO 算法对 GRU 模型的关键参数进行寻优,解决了 GRU 易陷入局部最优解的问题;使用 1949–2021 年全国粮食产量数据作为数据源,利用 PSO–GRU 模型对全国粮食产量进行预测,并与 GRU、PSO–RNN 和 PSO–LSTM 等模型进行比较分析。实验结果表明,PSO–GRU 模型能够充分挖掘时间序列特征,在全局收敛方面展现出显著优势,提高了粮食产量预测的准确性。

关键词: 粮食产量预测; PSO–GRU; 粒子群优化算法; 门控循环单元

中图分类号: TP183 文献标志码: A 文章编号: 2095–2163(2024)08–0109–06

Grain yield prediction based on Particle Swarm Optimization (PSO) and Gated Recurrent Unit (GRU)

YUAN Shiyi

(Institute of Agricultural Information, Chinese Academy of Agricultural Sciences, Beijing 100081, China)

Abstract: Grain output forecasting is an important issue related to national transportation and people's livelihood. In order to improve the accuracy of grain output forecasting, a new grain output forecasting model is proposed in this paper: Grain yield prediction model based on Particle Swarm Optimization–Gate Recurrent Unit (PSO–GRU). The model uses PSO algorithm to optimize the key parameters of GRU model, and solves the problem that GRU is easy to fall into the local optimal solution. In this study, the national grain production data from 1949 to 2021 was used as the data source, the PSO–GRU model was used to forecast the national grain production, and the comparison and analysis were made with other models (including GRU, PSO–RNN and PSO–LSTM). The experimental results show that the PSO–GRU model can fully explore the features of time series and show significant advantages in global convergence, thus improving the accuracy of grain yield prediction.

Key words: Grain yield prediction; PSO–GRU; Particle swarm optimization algorithm; GRU

0 引言

粮食安全是国家安全的基石,也是社会稳定、经济发展和民族复兴的重要保障。在建设农业强国和实施乡村振兴战略的过程中,保障粮食和重要农产品的稳定供应始终是头等大事和底线任务。尽管中国近年来粮食产量保持稳定增长,2021 年粮食生产总量达到 68 285 万吨,但受新冠疫情、全球气候变化以及国际紧张形势等因素的影响,中国粮食安全面临着多种风险和挑战。因此,开展粮食产量预测研究对于保障国家粮食安全和促进社会经济发展具有重要意义。粮食产量预测可以为国家农业规划和

经济决策提供科学的指导,帮助政府科学制定粮食储备、物资调拨等政策措施。同时,科学的粮食产量预测还能够为农业生产者提供参考和指导,帮助其更好地制定种植计划和市场销售策略。继续加强粮食产量预测方面的研究和应用,探索更为科学的粮食生产模式和管理机制,从而进一步提高粮食产量的稳定性和可持续性。

粮食产量预测方法主要包括传统的经验统计预测法、基于遥感技术的预测法以及利用机器学习方法的预测。经验统计预测法主要依靠历史统计数据 and 经验规律等进行预测,刘子玲等^[1]采用灰色回归模型对广州市的果蔬类生鲜农产品冷链物流的需求

基金项目: 国家自然科学基金(62103418);中国农业科学院农业信息研究所基本科研业务费项目(JBYW–AII–2024–30)。

作者简介: 袁世一(1988–),女,博士,助理研究员,主要研究方向:农业经济,粮食安全监测预警。Email: yuanshiyi@caas.cn

收稿日期: 2023–06–06

哈尔滨工业大学主办 ◆ 专题设计与应用

进行了预测;陈振坤等^[2]利用灰色关联模型对河南省的粮食生产情况进行预测;何延治^[3]采用时间序列分析法对吉林省的粮食产量进行了预测。遥感技术预测法主要是通过遥感技术获取粮食作物反射波长和频率数据,进而对粮食产量进行模拟分析^[4-5]。机器学习预测法主要通过机器学习算法对粮食产量历史数据进行模拟,伍丹华等^[6]采用BP(Back Propagation)神经网络对东台市的粮食产量进行了预测;高心怡等^[7]采用支持向量机预测模型预测了中国粮食的产量;贾梦琦等^[8]采用差分自回归移动平均模型(ARIMA)、广义回归神经网络模型(GRNN)以及长短期记忆人工神经网络模型(LSTM)预测了保定市的粮食产量。随着人工智能的发展,各种组合预测方法已在粮食产量预测中得到广泛应用,例如:庄星等^[9]、Zhang等^[10]利用粒子群和人工蜂群优化BP神经网络,并将其应用于中国粮食产量预测,取得了较好的预测效果;黄琦兰等^[11]提出了一种基于自适应差分进化(ADE)算法优化最小二乘支持向量机(LSSVM)的粮食产量预测模型,并将其应用于中国1975-2018年粮食产量预测中,具有较高的预测精度;陈灿虎等^[12]构建了一种基于差分进化改进灰狼优化的BP模型的粮食产量预测模型,与BP神经网络相比,其预测精度有大幅提升。陈晓玲等^[13]以贝叶斯全局优化(LightGBM调参)模型为基础分别预测了广西的早、晚水稻产量,与随机森林模型相比,其预测的准确性得到了提高;吴彬溶等^[14]采用注意力机制的(ADE-Bi-IndRNN)模型对中国的粮食产量进行了预测,并对中国粮食产业未来的发展提出了政策建议;徐宁等^[15]将机器学习与全球气候变化模式相结合,预测了埃塞俄比亚的粮食产量。在粮食产量预测方面,机器学习和人工智能技术的应用已成为趋势,各种组合预测方法也在不断涌现。为了进一步提高粮食产量预测的准确性,本文对GRU模型中的长时间序列和短时间序列的相互依赖关系进行充分挖掘,并利用PSO算法的全局收敛性和高效性,提出了一种基于PSO-GRU的粮食产量预测模型。通过与PSO-RNN、PSO-LSTM和PSO-GRU等预测结果比较发现,PSO-GRU模型在粮食产量预测方面准确性更高。

1 相关工作

1.1 粒子群算法

粒子群算法(PSO)是一种基于群体协作的启发

式优化算法,源于对鸟群觅食的行为研究^[16]。该算法将待求解问题看成一个在多维空间中寻找最优解的优化问题,将每个可能的解看成多维空间中的一个粒子,并将其随机散布在搜索空间中,通过不断迭代更新粒子的位置和速度,实现全局最优解的寻找^[17]。PSO算法具有算法简单、易于实现和收敛速度快等优点,已广泛应用于各个领域。PSO算法的具体步骤:

(1)构造初始粒子种群:随机初始化种群中粒子群的大小以及各粒子的位置和速度。

(2)计算适应度函数值:计算各粒子的目标函数,明确各粒子的当前个体极值,计算整个粒子群的当前全局最优解。

(3)更新各粒子的速度和位置:根据公式(1)和(2)更新各个粒子速度和位置:

$$v_i(t+1) = w \times v_i(t) + c_1 r_1 [pBest(t) - p_i(t)] + c_2 r_2 [gBest(t) - p_i(t)] \quad (1)$$

其中, $pBest$ 为粒子在 t 时刻的个体最优位置; $gBest$ 为粒子在 t 时刻的全局最优位置; w 为惯性因子; c_1 、 c_2 为加速因子; r_1 、 r_2 为 $[0,1]$ 之间的随机数。

$$p_i(t+1) = p_i(t) + v_i(t+1) \quad (2)$$

其中, p_i 为第 i 个粒子的空间位置, v_i 为第 i 个粒子空间位置变化速率。

(4)重新计算适应度:更新每个粒子的位置和速度后,需要重新计算其适应度值,比较当前结果和历史最优解 $pBest$ 以及全局最优解 $gBest$ 。

(5)终止条件判断:如果满足终止条件,则输出当前种群中的最优粒子并终止程序;否则,返回第(3)步进行迭代。

1.2 门控循环单元

门控循环单元(Gated Recurrent Unit, GRU)是一种基于递归神经网络(Recursive Neural Network, RNN)的机器学习算法,是对长短期记忆神经网络(LSTM)的改进。GRU模型采用独特的门控设计,能够自适应地选择性遗忘和更新序列中的信息,并充分挖掘序列数据的长期依赖关系^[18]。相比于传统的循环神经网络,GRU模型可以更好地解决梯度消失和梯度爆炸等问题,同时降低过拟合风险^[19]。GRU模型结构将LSTM的更新门和遗忘门结合为更新门,并合并了单元状态和隐藏状态,结构更加简单,模型训练速度更快,训练效率大幅提升^[20]。GRU由输入层、隐藏层、全连接层和输出层组成,其中隐藏层是链状结构,包括更新门和重置门,模型结构如图1所示。

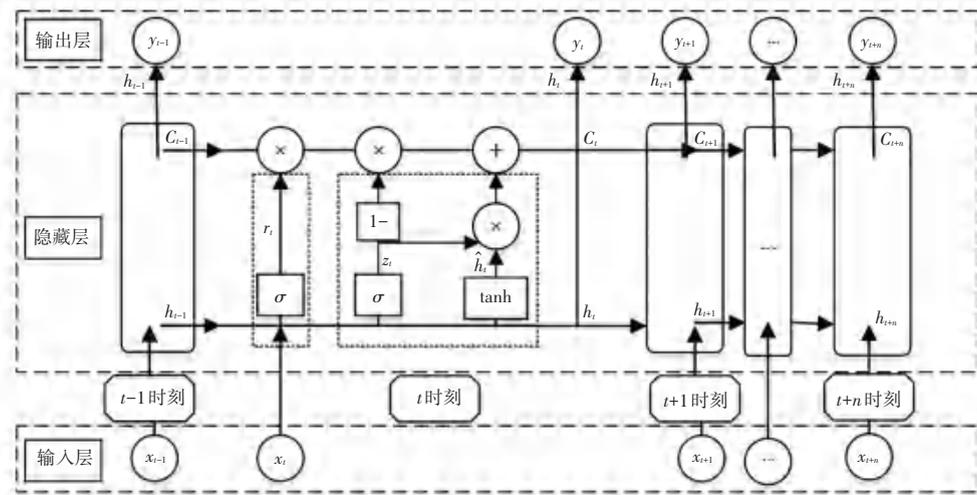


图 1 GRU 模型结构图

Fig. 1 GRU model structure diagram

在 GRU 模型中,有 3 个关键的门控单元:重置门 r_t 、更新门 z_t 和候选隐状态 h_t 具体计算如下:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (3)$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (4)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \hat{h}_t \quad (5)$$

其中, σ 为 Sigmoid 激活函数; \tanh 是双曲正切激活函数; \hat{h}_t 是 t 时刻的单元外部状态; W_r 、 W_z 分别为 t 时刻重置门和更新门的权值矩阵;“*”表示向量积。

1.3 PSO-GRU 预测模型

为提升粮食产量的预测精度,本文将 PSO 算法和 GRU 模型各自的优势相结合,构建基于 PSO-GRU 神经网络模型预报流程图如图 2 所示。

(1)数据预处理及标准化。对粮食产量数据进行预处理,将其划分为训练集、验证集和测试集,并对数据进行标准化处理;

(2)随机初始化粒子群。设置 PSO 模型的基本参数,包括种群规模、粒子数量及迭代次数等;

(3)初始化 GRU 各参数。确定时间窗口大小、批处理大小、隐藏层单元数目和训练次数;

(4)初始化各粒子适应度。根据各粒子对应的参数来构建 GRU 模型,利用训练数据对其进行训练;将验证数据输入到模型中,得到其预测结果,并计算预测结果与真实值之间的平均相对误差 (MAPE),作为该粒子的适应度值;

(5)记录全局和个体最优值。随机初始化一定数量的粒子群,并确定初始种群、全局最优粒子位置 $pbest$ 和局部最优粒子位置 $gbest$;

(6)更新各粒子速度和位置。计算出每个粒子

的最新速度和位置,并根据每个粒子最新位置对应的超参数构建 GRU 模型进行训练,以计算各粒子的适应度值;

(7)判断算法是否满足终止条件。若满足终止条件,则输出模型的最优超参数;否则,返回步骤 (5)继续执行,直至满足终止条件;

(8)使用最优超参数构建 GRU 模型,并对粮食产量数据进行训练,输出粮食产量的预测值。

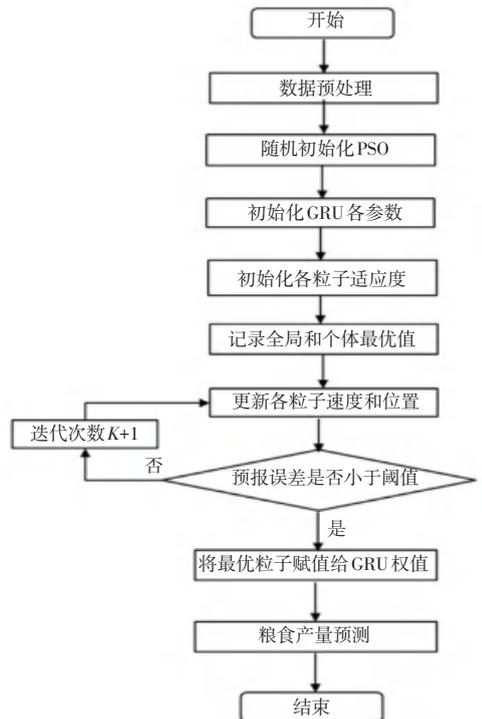


图 2 PSO-GRU 神经网络模型预报流程图

Fig. 2 PSO-GRU neural network model forecast flow chart

2 实验

2.1 数据来源

为验证 PSO-GRU 粮食产量预测模型的有效性和可靠性,本文选取了 1949-2021 年全国粮食产量数据作为研究对象,数据来源于《中国统计年鉴》。

2.2 数据预处理

数据预处理是为了消除原始数据波动性较大对预测结果的影响,可提高模型的预测速度和预测精度。本文采用归一化 (mapmaxmin) 函数对全国历年产量数据进行归一化处理。经此处理后的指标数值按固定比例缩放至 $[0, 1]$ 范围内,公式(6):

$$y = \frac{(y_{\max} - y_{\min})(x - x_{\min})}{x_{\max} - x_{\min}} + y_{\min} \quad (6)$$

其中, x_{\max} 和 x_{\min} 分别表示粮食产量数据对应的最大值和最小值; y_{\max} 和 y_{\min} 分别代表 x_{\max} 和 x_{\min} 归一化后对应的最大值和最小值; x 为粮食产量数据统计值。

2.3 模型评价指标

本文采用了多种评估指标,包括均方误差 (MSE)、均方根误差 (RMSE)、平均相对误差 (MAPE) 和平均绝对误差 (MAE),从鲁棒性和泛化性等方面对不同预测模型的性能进行评估。各评估指标的计算公式如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n [y_c(i) - y_0(i)]^2 \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n [y_c(i) - y_0(i)]^2}{n}} \quad (8)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_c(i) - y_0(i)}{y_0(i)} \right| \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_c(i) - y_0(i)| \quad (10)$$

其中, $y_0(i)$ 为粮食产量实测值; $y_c(i)$ 为粮食产量预报值; n 为模型测试样本数。

各评估指标反映粮食产量实测值与预报值之间的差异程度, MSE 、 $RMSE$ 、 $MAPE$ 和 MAE 值越小,代表模型预测精度越高。

2.4 参数确定

本文采用 2007-2021 年共 15 年的粮食产量数据作为测试集,其余 (1949-2006 年) 粮食产量数据作为训练集。为了避免过拟合、提高模型的泛化能力,使用交叉验证的方法,将训练集划分为训练集和验证集,训练集占 80%,验证集占 20%。

根据 PSO-GRU 预测模型的参数设置,将时间窗口大小、批处理大小、隐藏层单元数目和训练次数等超参数设置为 GRU 模型的超参数。由于其他参数变化可能对预测结果产生影响,为了保证实验的准确性和可靠性,将各模型的学习率均设置为 0.001, dropout 比率均设置为 0.2,其中粒子群粒子个数为 30,最大迭代次数为 300,速度惯性权重 ω 为 0.6,加速系数和为 2。同时,通过不同参数测试及逐参数微调的方法,进一步确定了 GRU 超参数的取值范围,包括时间窗口大小取值范围为 $[5, 20]$,批处理大小取值范围为 $[1, 60]$,隐藏层单元个数取值范围为 $[10, 30]$,训练次数取值范围为 $[100, 900]$ 。

通过 PSO 算法分别得到了 PSO-RNN、PSO-LSTM 及 PSO-GRU 模型的最优超参数。选取了时间窗口大小、批处理大小、隐藏层单元数目和训练次数等超参数,采用网格搜索的方法对其进行调优,确定各模型的最优参数设置见表 1。

表 1 模型参数汇总

Table 1 Summary of model parameters

模型	时间窗口	批处理	隐藏层单元	训练数
PSO-RNN	12	48	44	800
PSO-LSTM	15	48	48	800
PSO-GRU	15	58	50	800

2.5 预测结果对比与分析

为提高粮食产量的预测精度,本文采用全国粮食产量数据和 31 个省粮食产量数据进行预测,将各省市的预测结果相加,与全国粮食产量数据比较。为验证 PSO-GRU 模型的优越性和有效性,本文还将其应用于粮食产量预测中,将其预测结果与其他模型预测结果进行比较。在 Keras 框架下实现了 6 种网络模型的仿真实验。通过输出层将处理后的数据转化为预测值,并使用均方误差作为损失函数进行优化。PSO-GRU 模型采用基于自适应学习原理的 Adam 算法来优化 GRU 模型内部参数。Adam 算法能够自适应地根据每个参数的梯度大小和方向来更新参数的学习率,避免了学习率的手动调整问题。同时,为了进一步优化模型性能,PSO-GRU 模型还采用网格搜索法对模型的各关键参数进行调优,从而得到最优的超参数组合。预测结果如图 3 所示,6 种预测模型中各省预测数据之和的效果均优于全国数据的预测效果。

以 PSO-GRU 预测模型为例,全国粮食产量预测、各省市粮食产量预测之和对应的 $MAPE$ 分别为 4.5%、2.6%,通过更细致的区域划分,提高预测的精

度和准确性。由于不同省市间存在着显著差异的气候、土地利用等因素,粮食产量的波动也很大,因此综合考虑各省市的粮食产量数据能够更好地反映全国的粮食产量情况。不论是哪种预测模型,在使用各省市粮食产量数据之和进行预测时都显示出优于全国粮食产量数据的预测效果。PSO-GRU 模型在各省市粮食产量和全国粮食产量两种预测方法中均表现出很好的预测效果,进一步验证了该模型的有

效性和泛化能力。

根据图 3 还可以看出,在 PSO-GRU 模型优化下预测精度均有所提高,PSO-GRU 模型的预测结果在数值与变化趋势上与实测值最为接近,预测效果优于其他模型,说明 PSO-GRU 模型具有良好处理时间序列特征的能力,能够充分挖掘相隔较长时间粮食产量间的关联性,提高粮食产量预测的精度。

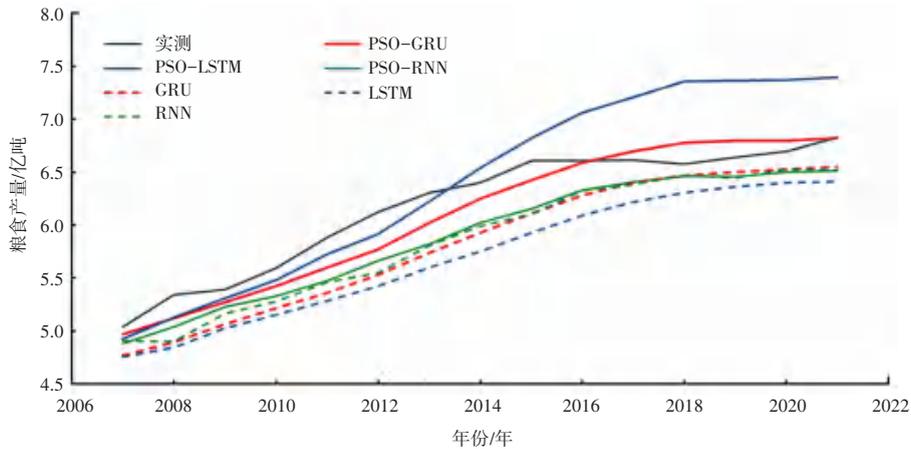


图 3 各模型预测结果对比图

Fig. 3 Comparison of prediction results of each model

全国 31 个省粮食产量预测精度评价指标见表 2。PSO-GRU 模型的各项评价指标均优于其他模型。相较于 PSO-RNN 和 PSO-LSTM 预测模型,PSO-GRU 模型的 *MSE* 指标分别降低了 64.9% 和 80.7%, *RMSE* 指标分别降低了 40.8% 和 56.1%, *MAE* 指标分别降低了 45.3% 和 53.4%, *MAPE* 指标分别降低了 44.4% 和 50.7%。对比分析结果表明,本文提出的 PSO-GRU 模型具有良好的稳定性和泛化能力,可有效提高粮食产量预测精度。

表 2 各模型预报精度的评估指标

Table 2 Evaluation indexes of prediction accuracy of each model

预测模型	<i>MSE</i>	<i>RMSE</i> / 亿吨	<i>MAE</i> / 亿吨	<i>MAPE</i> / %
RNN	1 235	0.35	0.32	5.25
LSTM	2 479	0.50	0.47	7.70
GRU	1 489	0.39	0.35	5.84
PSO-RNN	986	0.31	0.29	4.73
PSO-LSTM	1 794	0.42	0.34	5.33
PSO-GRU	346	0.19	0.16	2.63

3 结束语

本文提出的 PSO-GRU 的粮食产量预测模型,结合了 GRU 模型能够充分挖掘长时间序列和短时间序列中粮食产量间的相互依赖关系以及 PSO 模

型全局收敛性和高效性的优势。通过实验验证,该模型在粮食产量预测方面具有良好的预测性和准确性,为粮食产量预测提供了新思路,从而为国家粮食安全决策提供理论依据。

(1) 对各省粮食产量预测后求和的效果优于全国粮食产量数据,因此综合考虑各省市的粮食产量数据能够更好地反映全国的粮食产量情况;

(2) 在 PSO 算法的优化下,PSO-GRU 模型预测结果的各项指标均优于其他预测模型,具有良好的处理时间序列特征的能力,能够充分挖掘相隔较长时间粮食产量间的关联性,提高粮食产量预测的精度;

(3) 由于粮食产量影响因素众多,且各影响因素与粮食产量均存在不确定的非线性关系,并且在时间维度上具有关联性。本文仅根据历史数据对粮食产量进行预测,未考虑可能影响粮食产量的因素。后续将对粮食产量的影响因素进行分析,并以此作为模型的输入因素,进一步提高粮食产量的预测精度。

参考文献

[1] 刘子玲,谢如鹤,廖晶,等. 基于灰色回归模型广州市果蔬类生鲜农产品冷链物流需求预测 [J]. 包装工程, 2024, 45 (3):

- 243-250.
- [2] 陈振坤,贾积身. 基于分数阶灰色模型的河南省粮食产量预测[J]. 中国农机化学报, 2022, 43(6): 135-141.
- [3] 何延治. 基于时间序列分析的吉林省粮食产量预测模型[J]. 江苏农业科学, 2014, 42(10): 478-479.
- [4] WAN L, CEN H, ZHU J, et al. Grain yield prediction of rice using multi-temporal UAV-based RGB and multispectral images and model transfer—a case study of small farmlands in the south of China [J]. *Agricultural and Forest Meteorology*, 2020, 291: 108096.
- [5] HAGHIGHATTALAB A, CRAIN J, MONDAL S, et al. Application of geographically weighted regression to improve grain yield prediction from unmanned aerial system imagery [J]. *Crop Science*, 2017, 57(5): 2478-2489.
- [6] 伍丹华,周礼梅. 基于BP神经网络的粮食产量预测[J]. 农业工程技术, 2020, 40(27): 51-53.
- [7] 高心怡,韩飞. 基于混合智能算法的支持向量机的粮食产量预测[J]. 江苏大学学报(自然科学版), 2020, 41(3): 301-306.
- [8] 贾梦琦,蔡振江,胡建,等. 基于机器学习的粮食产量预测模型研究[J]. 河北农业大学学报, 2021, 44(3): 103-108.
- [9] 庄星,韩飞. 基于混合群智能算法优化BP神经网络的粮食产量预测[J]. 江苏大学学报(自然科学版), 2019, 40(2): 209-215.
- [10] ZHANG L, LIU J, ZHI L. Research on grain yield prediction method based on improved PSO-BP [J]. *Journal of Electrical Engineering*, 2014, 12(10): 7404-7411.
- [11] 黄琦兰,彭正昌. 基于ADE-LSSVM算法的粮食产量预测研究[J]. 粮食与油脂, 2021, 34(11): 36-40.
- [12] 陈灿虎,陈英伟. 基于差分进化改进灰狼优化的BP模型的全国粮食产量预测[J]. 农业与技术, 2023, 43(5): 167-171.
- [13] 陈晓玲,张聪,黄晓宇. 基于Bayesian-LightGBM模型的粮食产量预测研究[J]. 中国农机化学报, 2024, 45(6): 163-169.
- [14] 吴彬溶,王林. 基于注意力机制的ADE-Bi-IndRNN模型的中国粮食产量预测[J]. 运筹与管理, 2024, 33(1): 102-107.
- [15] 徐宁,李发东,张秋英,等. 基于机器学习和未来气候变化模式的埃塞俄比亚粮食产量预测[J]. 中国生态农业学报, 2024, 32(3): 490-506.
- [16] 王康,龚文杰,段晓燕,等. 基于PSO算法优化GRU神经网络的短期负荷预测[J]. 广东电力, 2020, 33(4): 90-96.
- [17] 宋刚,张云峰,包芳勋,等. 基于粒子群优化LSTM的股票预测模型[J]. 北京航空航天大学学报, 2019, 45(12): 2533-2542.
- [18] 苑希民,黄玉啟,田福昌,等. 基于LSTM-GM神经网络模型的风暴潮增水预报方法[J]. 水资源保护, 2023, 39(6): 8-15.
- [19] 高翱,王帅,韩兴臣,等. 基于GRU神经网络的WGAN短期负荷预测模型[J]. 电气工程学报, 2022, 17(2): 168-175.
- [20] 王博文,王景升,王统一,等. 基于卷积神经网络与门控循环单元的交通流预测模型[J]. 重庆大学学报, 2023, 46(8): 132-140.